5 个不为人知的 PDF 技巧 | 实用技巧

Minja　2018年12月31日

工作、学习中，我们都没少和 PDF 文档打交道。

PDF 能流行开来，功劳就在其**兼容性好**，本世纪的设备基本都能打开、打印时所见即所得、传给别人不用担心格式丢失或出错……以至于我和同事曾经调侃：**简单说，PDF 就是一张图片。**

不过，如果你想对 PDF 做一些超出「图片范畴」的操作，问题就接踵而至了。这篇文章里，就收集了 5 类疑难杂症，相信不少人都遇到过：

1. **PDF 边儿太宽**，浪费空间；
2. **PDF 里全是别人的批注**，影响我阅读；
3. **PDF 居然有密码**，没法在上面批注、记笔记；
4. **扫描版 PDF 里的字没法搜索**，只能看着它干瞪眼；
5. **想把 Word 文档或其他文件转换成 PDF**，一个一个来嫌太慢。

这些问题遍布 PDF 的生成、传播到阅读、批注，而由于 PDF 的「图片」特性，我们没法像改 Word 文档一样轻松地修改 PDF，需要另辟蹊径。**本文将解决以上所有顽疾。**

上述部分问题没有现成解决方案，所以**我会提供 3 个原创的**

自动化动作。考虑到大家用的工具各不相同，我统一提供通用的 Automator 版本，安装后可以在右键菜单取用。各个第三方工具的玩家可以自行改造，做出适合自己操作习惯的动作。

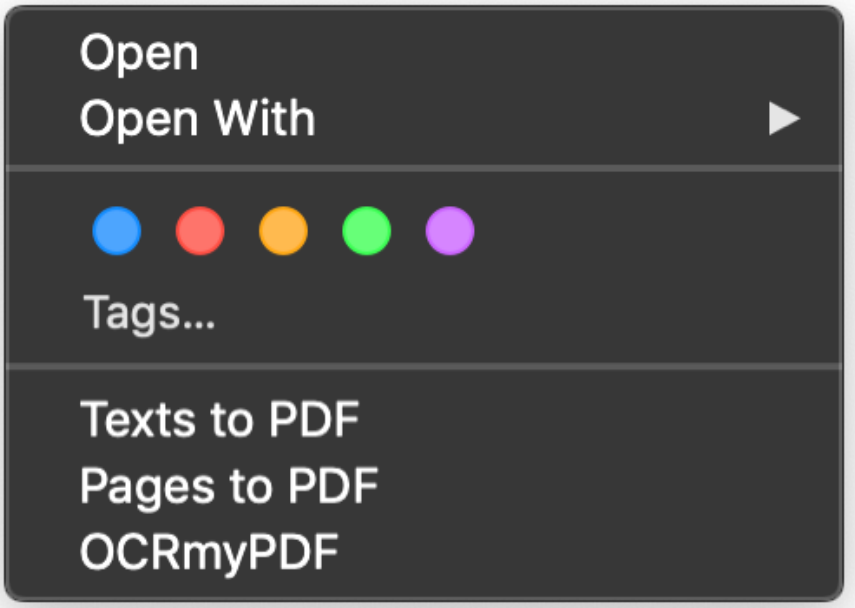

本文所有工具都可以在右键菜单取用

注：本文技巧仅供个人使用，请勿用于传播盗版资源——事实上，这些方法也入不了有批量生产需求的盗版商之眼。

技巧一：去除白边

「白边」是 PDF 文件的特色。有些白边是特意留出来放页码、页眉的，有些则是扫描时一同扫进去的白底[1]

，但总而言之，它们挺很浪费屏幕空间，特别在 Kindle、小平板等小尺寸设备上，文字会被压缩好几圈。

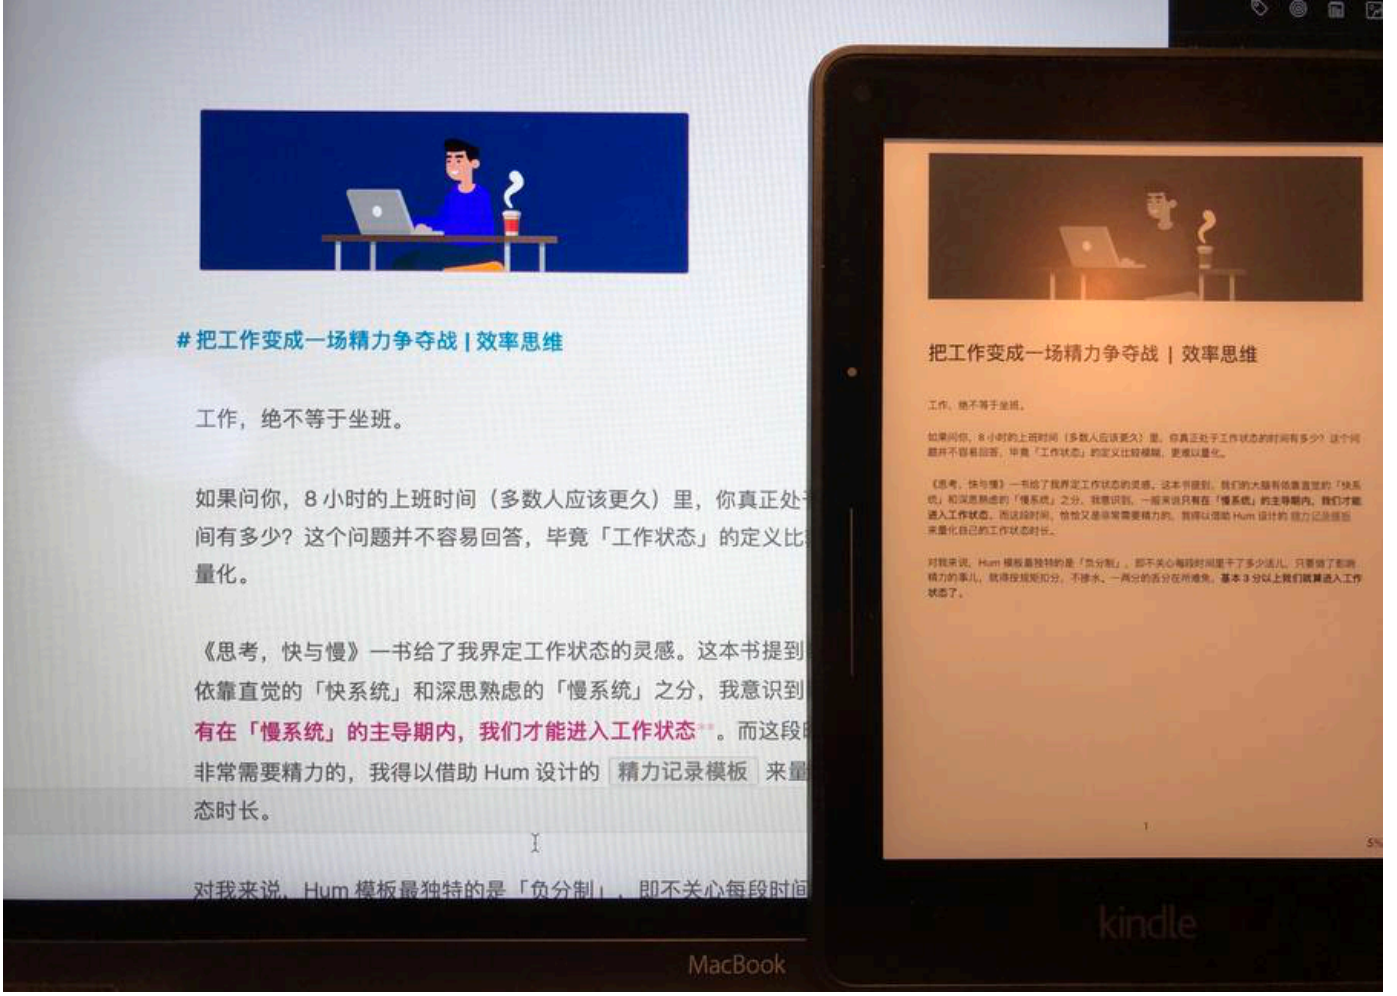

用 Kindle 看没裁过的 PDF，往往挺遭罪

去除白边有很多思路，我们用两种 macOS 原生的。**一种是重新打印，另一种是手动裁剪**，各有优劣，我们分别介绍。

重新打印

macOS 自带的打印功能可以按比例缩放 PDF，从而裁出比较整齐的新 PDF 文档。直接用预览工具打开 PDF 文件：

1. 勾选「缩放」，填入数值。留意一下左侧预览窗口，感觉白边差不多没了就行了。
2. 选择左下角「存储为 PDF」。

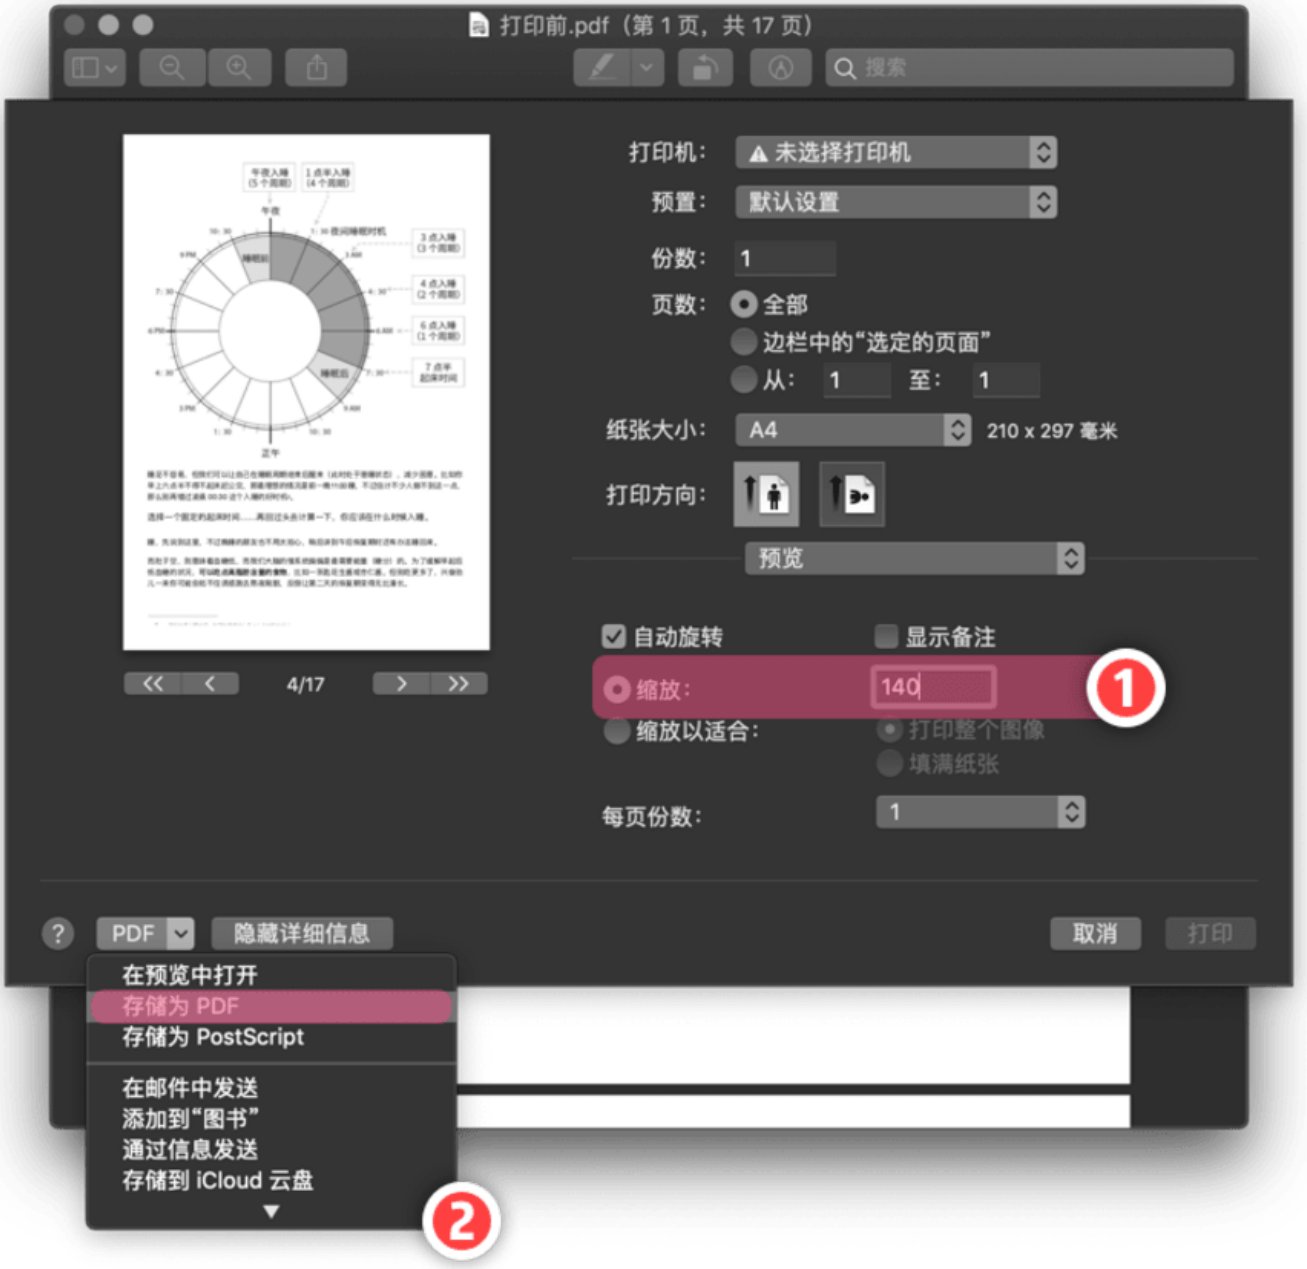

重新打印

重新打印后的 PDF 文件图文内容明显大了一圈，如果你需要在 Kindle 上阅读，也可以把数值填大一些，把页码一起切除。

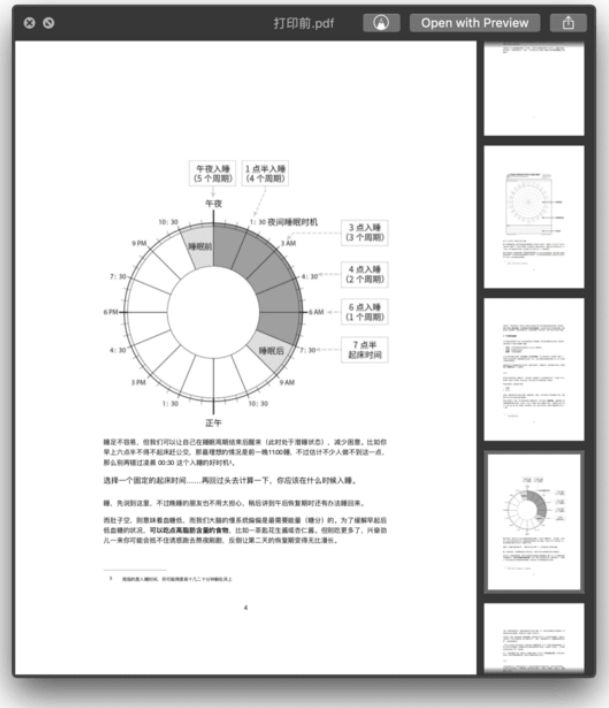

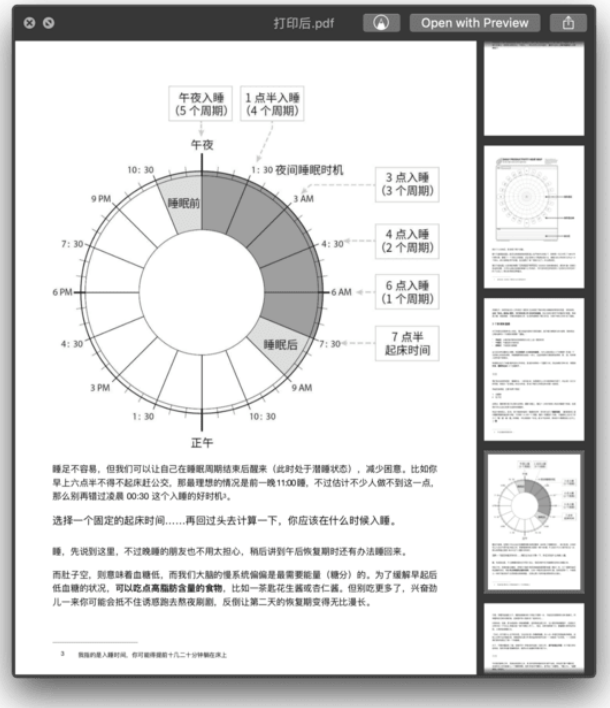

打印后白边小了很多

不过打印的缺陷也比较明显，需要 PDF 本身比较规整，可很多扫描版 PDF 的白边分布很随机，没法通过打印通吃它们[2]

，这时候就需要手动裁剪了。

手动裁剪

听到「手动」两字不用怕，**其实还是可以批量处理的**。仍然用预览工具打开 PDF：

1. 点击左上角的按钮，开启「缩略图」视图；
2. 按下 ⌘Command – A，选中所有页面；
3. 点击「菜单栏 - 工具 - 矩形选择」；
4. 选中需要留下的区域，按 ⌘Command – K 进行裁剪。

裁剪前可以发现，尽管只在 PDF 其中一页进行了选取，但选

区被应用到了所有页面——因为我们已经提取选中了它们，**从而实现批量处理**。开一方面，相比重新打印，裁剪还可以更灵活：

1. 选区能自行调整，不一定非得是 A4 纸[3] 的长宽比；
2. 如果部分页面如果裁不齐，可以单独再行修剪。

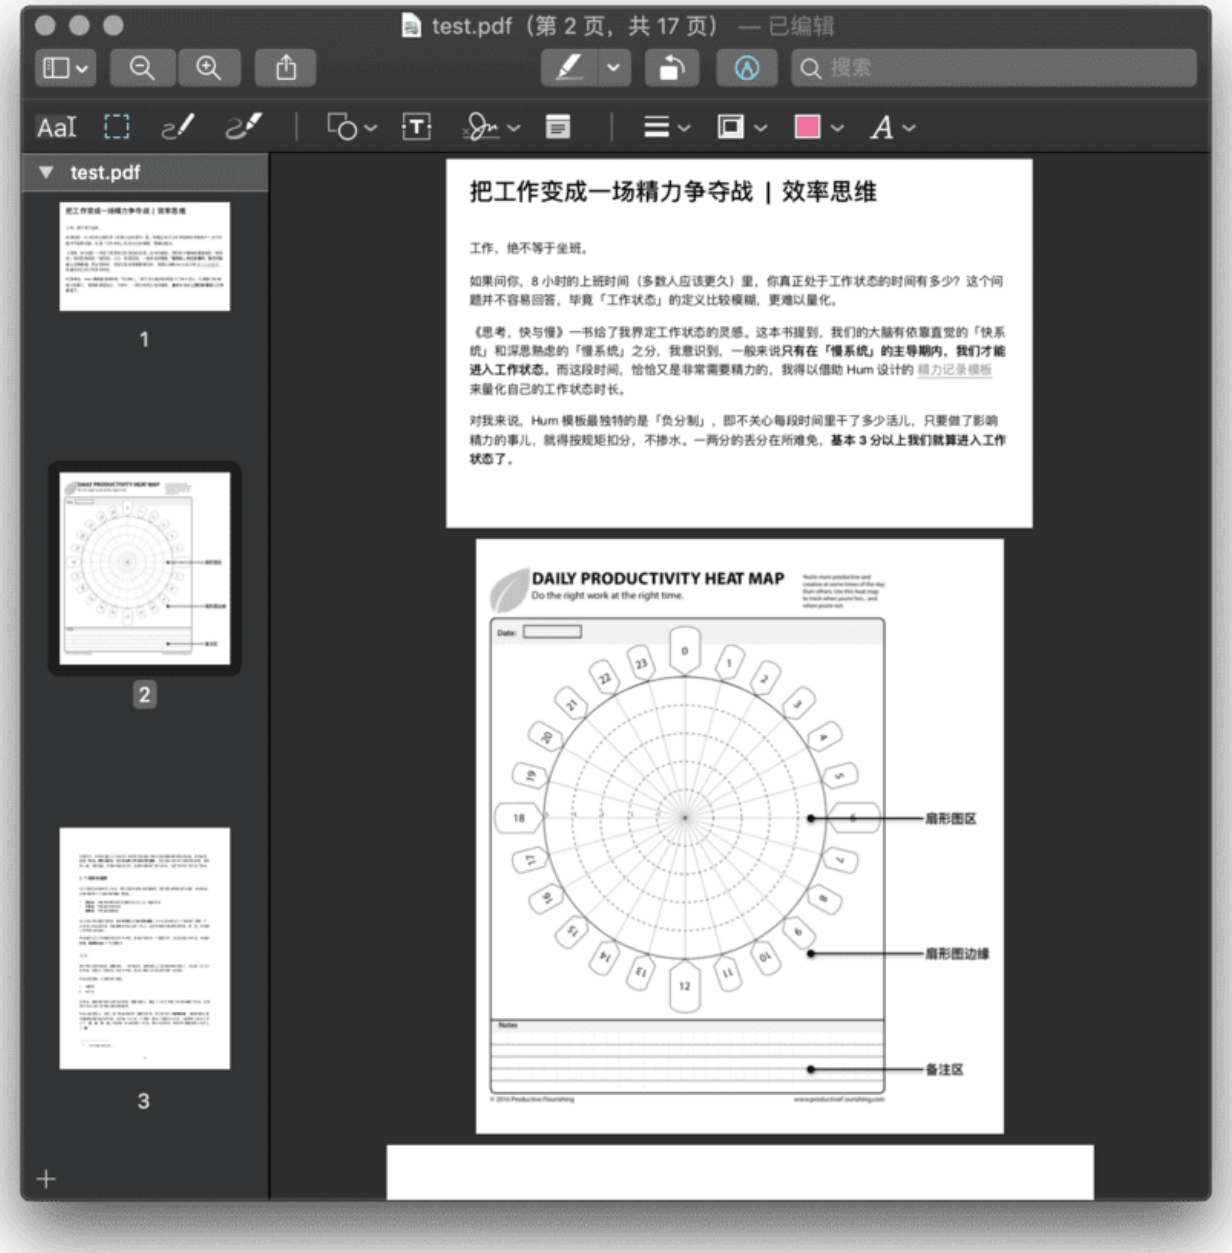

手动裁剪时，不同页面可以裁成不同大小

不过手动裁剪也有问题，**首先就是很难裁整齐**。如果你的阅读器能够显示 PDF 封面（基本都能显示，逃不掉的），那你将获得一排参差不齐的书籍封面，看着很碍眼。

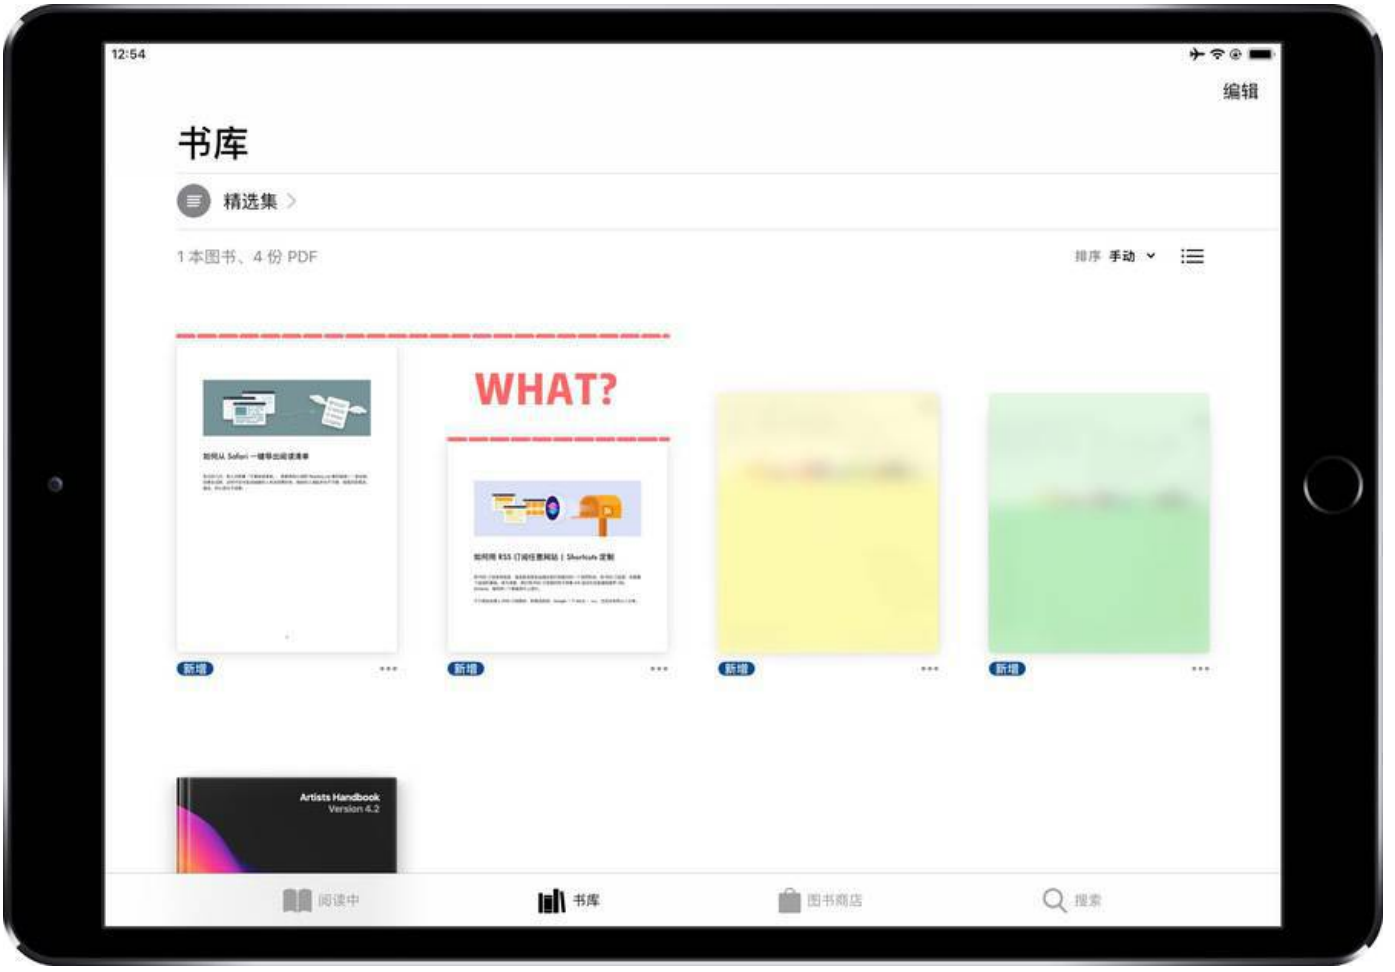

高低不齐的封面看着很难受

另外，扫描版的 PDF 文件往往体积巨大，动几十上百兆，而裁剪操作仅是隐藏边上的部分，并没有删除它们，**裁好后文件体积不会减小**。

总之，如果想裁得整齐、精巧，又不在意目录，那可以重新打印；如果需要保留目录，那还是手动裁剪。

技巧二：去除批注

有些 PDF 流传了几代，交到我们手里时已经画满了前人的标记。这些用功的痕迹，很大程度上也影响了正常的阅读、批注。

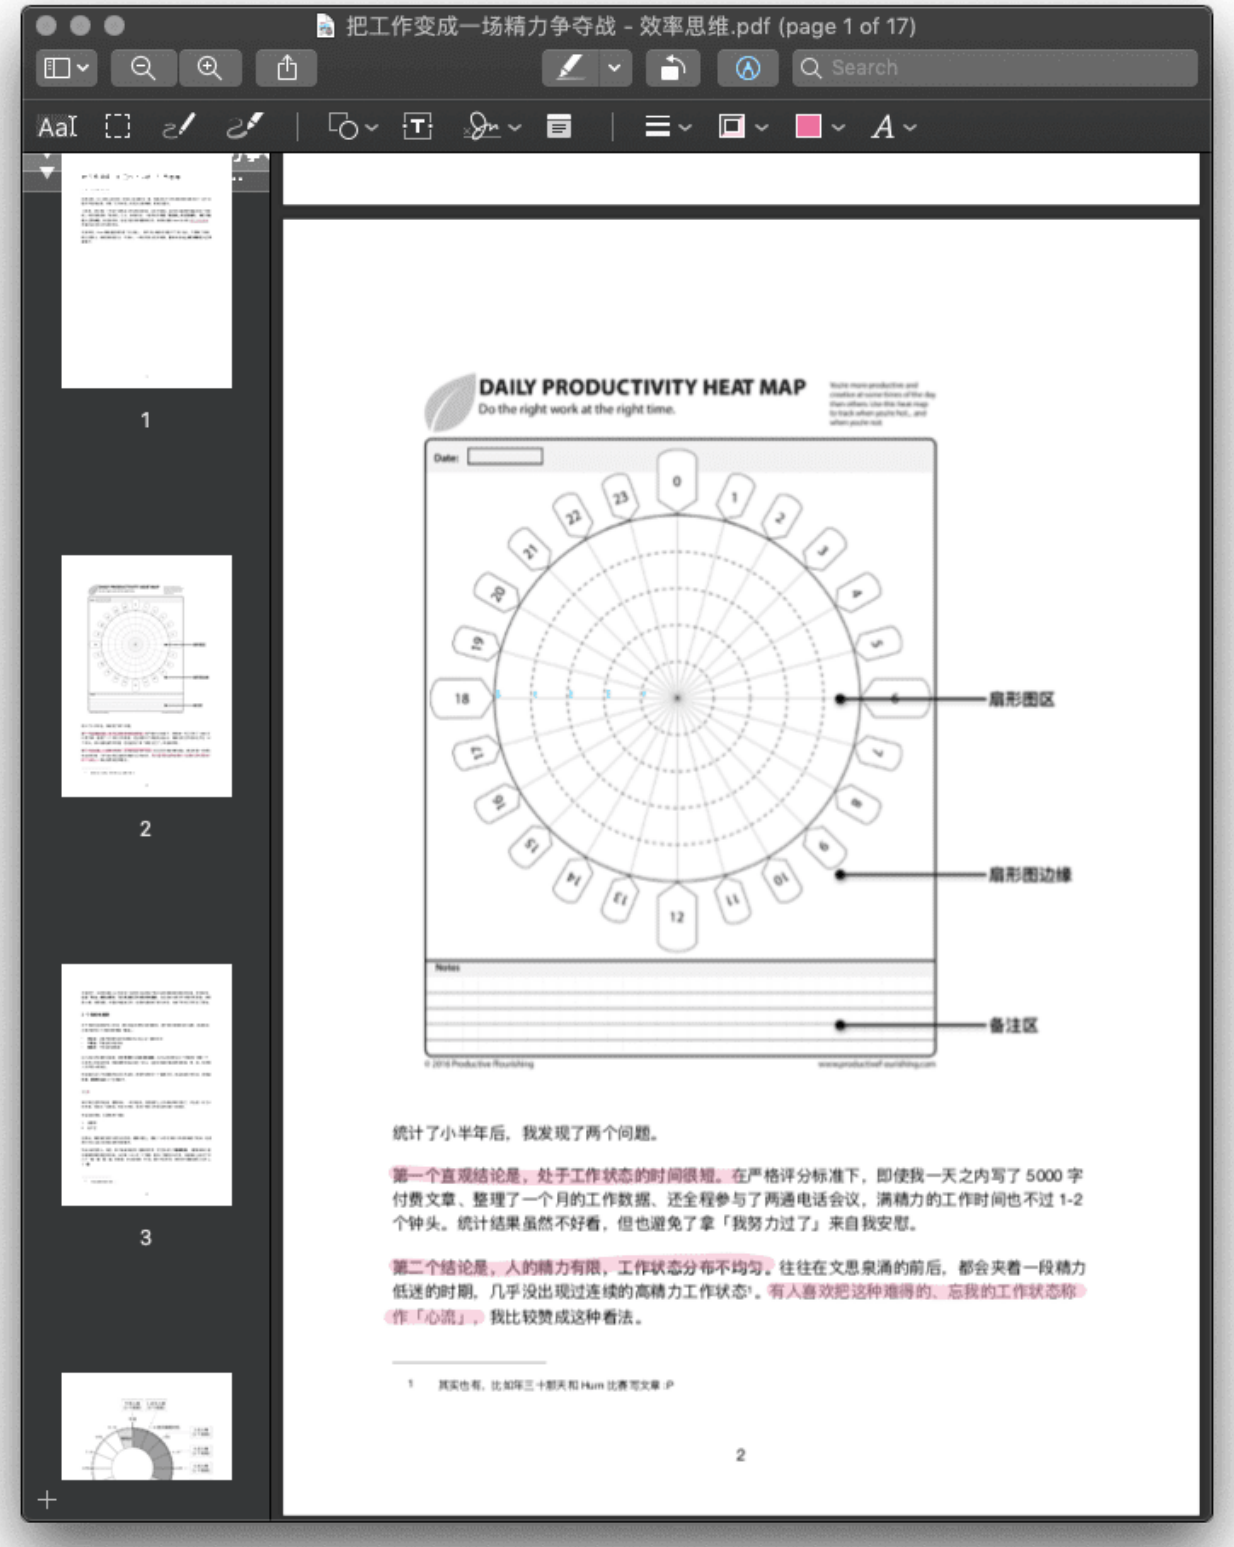

画满了批注的PDF

虽说 PDF 可以看作一张「图」，但它可能也是分层的，批注就是最顶端的「图层」，能够选中后删除。

PDF 其实是分层的

不过文档里的批注出没无常，就算有耐性一个一个手动删，也不一定拔得干净。PDF Expert、Adob PDF Acrobat 这些专业工具倒是能够批量消灭批注，但它们价格实在太高，这里介绍一个不花钱的工具：**iOS 上的 PDF Viewer**。

PDF Viewer 是那种讨人喜欢的小巧阅读器，原生界面，简单的导入导出功能、必要的批注工具，最重要的是可以导出纯净版 PDF，不含标注。

PDF Viewer 可以导出不带批注的 PDF

没有多余的步骤，一份干净的 PDF 就出现了。

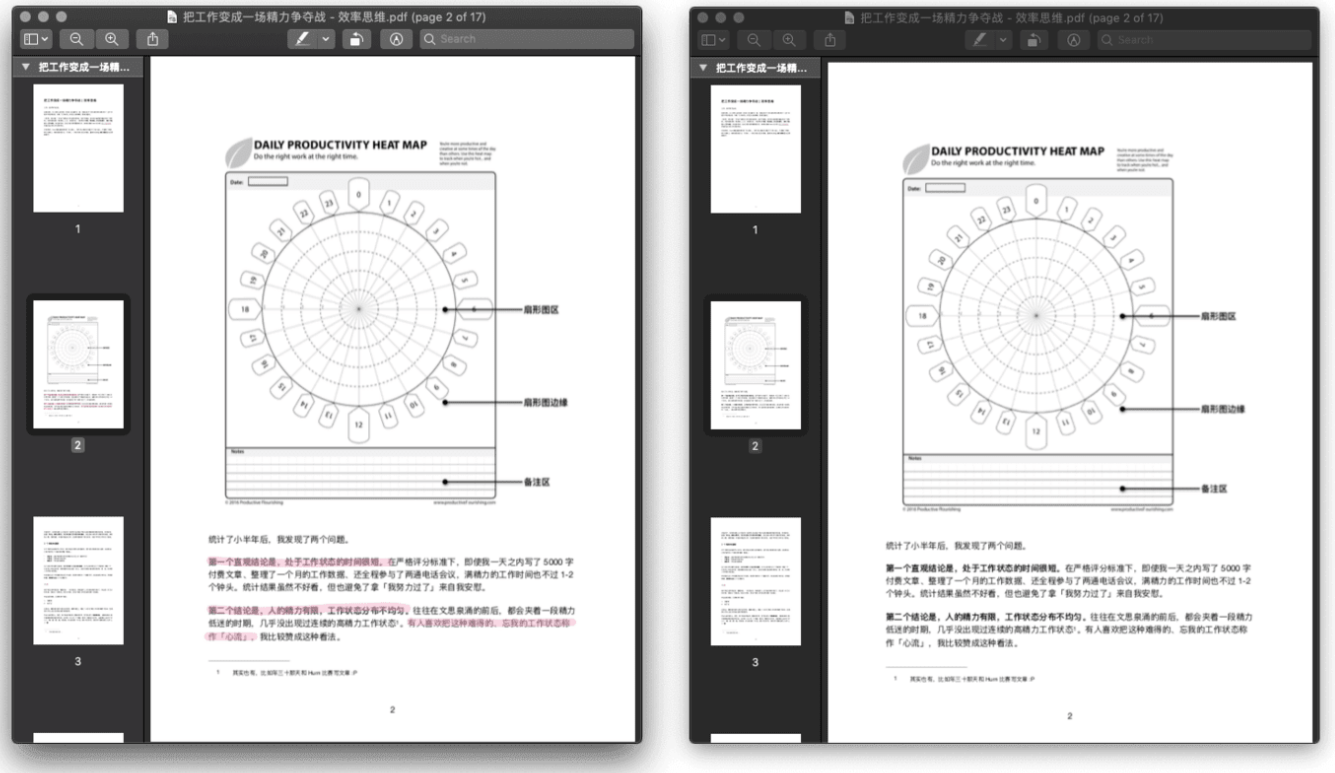

去除批注前后

对了，如果你下载了一份插满推广链接的 PDF——尤其是那种不小心碰一下就会弹到浏览器的烦人链接——上述方法或许也能起到批量清理作用。

技巧三：绕过编辑密码

有些 PDF 能打开阅读，但是不能编辑，做笔记也不行，很头疼。这就是遇到拥有者密码（Owner Permission Password）了。

初衷是好的，但有时也会给自己人带来不便。读书时就有这种情况，系里祖传的一些 PDF 书籍，当年的制作者不知何处高就去，只留密码挡我路，在我们看到精彩处、大笔一挥想记点东西时，发现没有权限编辑。

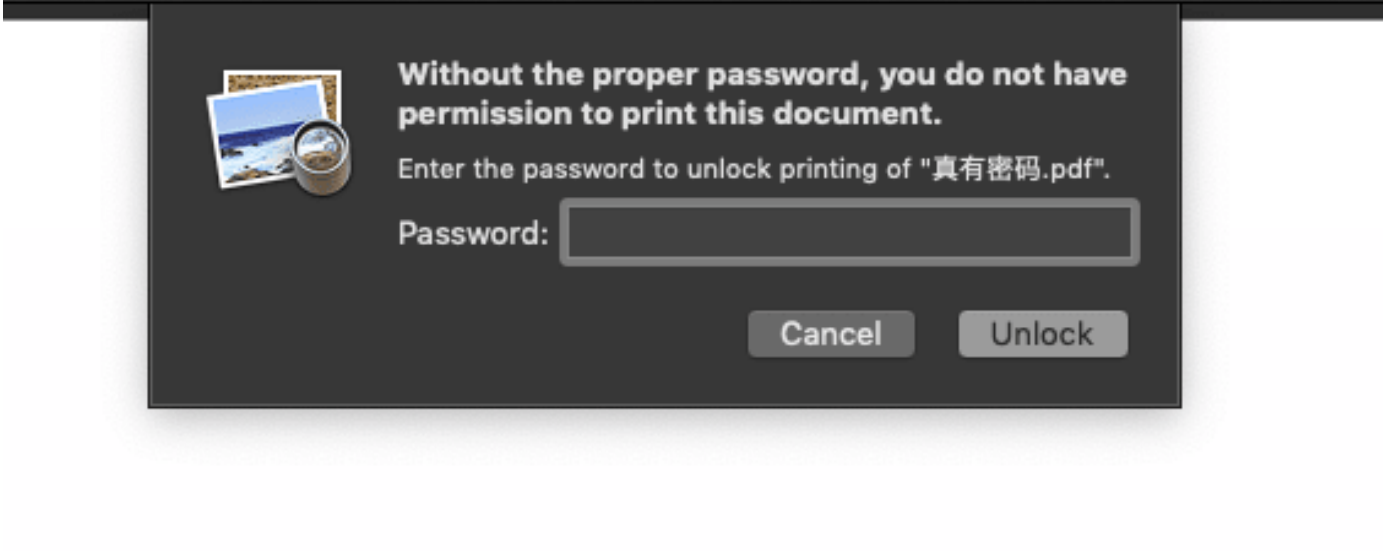

编辑密码严重影响做笔记

好在这类编辑密码也有办法绕过的：不用什么「破解」，**只需要一个 Google Drive 网盘**。

1. 先确认一遍，你遇到的的确是拥有者密码，如果连打开都不给打开，你还是找提供 PDF 的人讨密码吧；确认后，**把想编辑的 PDF 文档上传到 Google Drive**。到这一步，事儿就成了一半了。

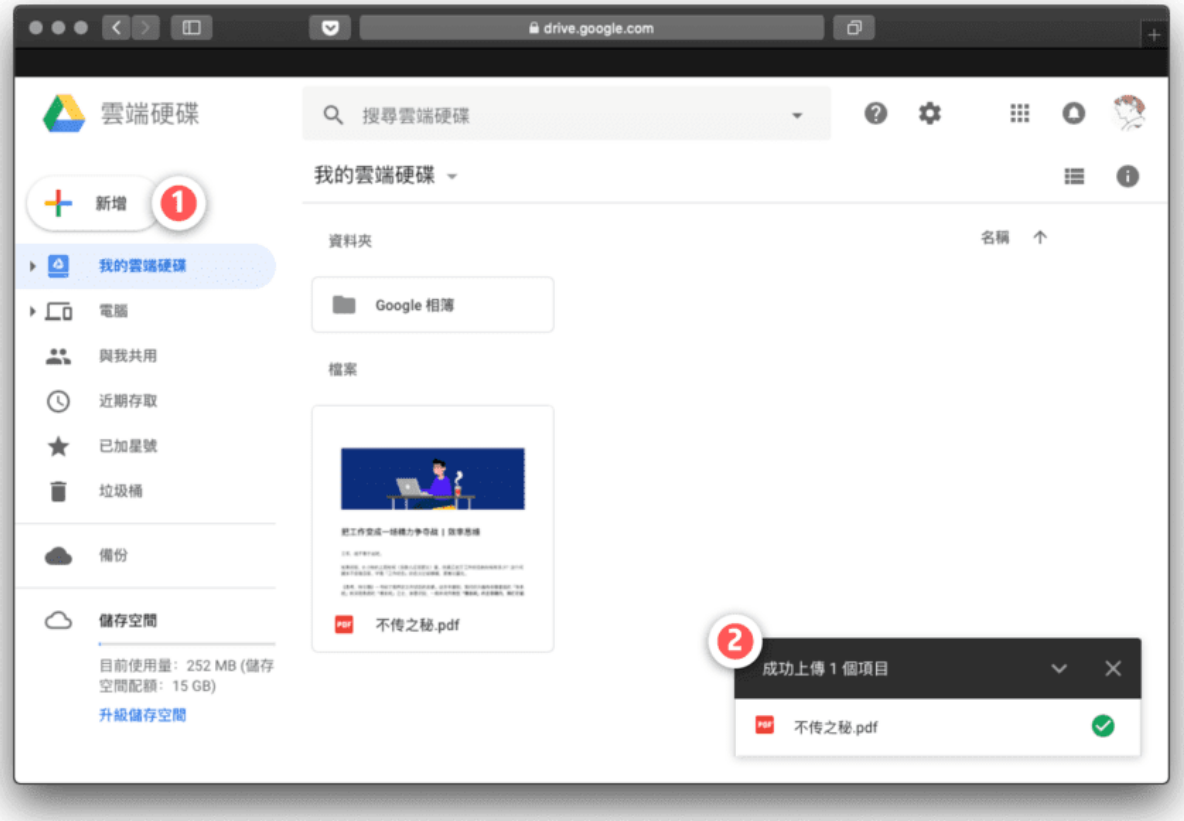

上传 PDF 到 Google Drive

2. 接着就省力了，在 Google Drive 里点击查看 PDF，**点击右上角的打印按钮**，静待一分钟，不带密码的 PDF 就生成了，Google Drive 会帮你打开一个预览的页面。

在 Google Drive 中打印 PDF

3. **最后点击预览界面的下载按钮**，新 PDF 就躺在了你的下载文件夹。如果没看到下载按钮，就在页面中下方晃几下鼠标把它召唤出来。

下载没有密码的 PDF 到本地

说到底，这个技巧的原理只是把你看到动东西重新打印了一遍，其他网盘或在线文档协作工具可能也支持，大家不妨自己测试一下，如果有能在国内可用的服务就更好了。

之前坊间流传过用 Chrome 浏览器重新打印来「解锁」密码的方子，不过在最新版本的浏览器中已经失效。我做了些测试，当前版本的 Chromium、Firefox、Safari 等浏览器均无法直接打印带密码的 PDF。

此外，网上还有一些破解 PDF 密码的站点，需要上传原始 PDF 文件，无论出于版权还是安全因素考虑，这里并不推荐[4]

。当然，如果是一些从不可言说网站下载来的 PDF，连解

压/打开密码都不知道，那就无能为力了 🤷

技巧四：将扫描版 PDF 转换成可搜索的文档

读过扫描版 PDF 的人，都知道那种**能看不能搜**的感觉是多么难受。不巧，有些老教材又只有扫描版，似乎只好硬着头皮人肉检索。

@契丹神童 曾经在 Power+ 1.0 介绍过 ocrmypdf 这个命令行工具，**能够给扫描件填上一层文字层，使得文本能够被搜索**；我据此做了一个 Automator 动作，这样，不用买第三方工具也可以享受 OCR 功能。

测试.pdf (1 page)
ocr
Sort by: Search Rank Page Order
Done
ocrmypdf 的命令较多，我们只介绍一条：**处理中英双语 PDF 文件**。如果把 原文件路径 和 新文件路径 填成同一条路径，就可以在 OCR 处理完后覆盖掉原 PDF 文档。
ocrmypdf 原文件路径 新文件路径 -l chi_sim+eng --force-ocr
接着，我们把这条命令用到 Automator 里面。方便起见，我们做一个覆盖原文件的版本（不然就要涉及一些诡异晦涩的变量语法，大家感兴趣的话我会另写一篇文章）。
把 PDF 拖上去，稍等一会儿就识别好了。
测试.pdf (1 page)
ocr
Sort by: Search Rank Page Order
Found on 1 page
Done
ocrmypdf 的命令较多，我们只介绍一条：**处理中英双语 PDF 文件**。如果把 原文件路径 和 新文件路径 填成同一条路径，就可以在 OCR 处理完后覆盖掉原 PDF 文档。
ocrmypdf 原文件路径 新文件路径 -l chi_sim+eng --force-ocr
接着，我们把这条命令用到 Automator 里面。方便起见，我们做一个覆盖原文件的版本（不然就要涉及一些诡异晦涩的变量语法，大家感兴趣的话我会另写一篇文章）。
把 PDF 拖上去，稍等一会儿就识别好了。

ocrmypdf 处理过的文件能被搜索

> 动作下载 🔗

光装好动作，还不能直接用，需要安装和配置一下 ocrmypdf。**下面是安装 ocrmypdf 及中文语言包的脚本，直接复制到终端中运行即可。**截至写这篇文章，tesseract 的最新版本是 3.05.02，如果下载语言包失败，请到 `/usr/local/Cellar/tesseract/` 下检查一下你的版本是多少，并把命令里的旧版本号 `3.05.02` 替换掉。

```
# 安装脚本
brew install ocrmypdf
wget -o
/usr/local/Cellar/tesseract/3.05.02/share/tessdata/chi_sim.tra
 https://github.com/tesseract-
ocr/tessdata/raw/master/chi_sim.traineddata
```

装好动作、配置完成后，OCR 功能就会出现在右键菜单里。

挑一个扫描版或图片版本的 PDF 识别一下，短则几秒钟，长则几分钟，具体要看 PDF 大小。

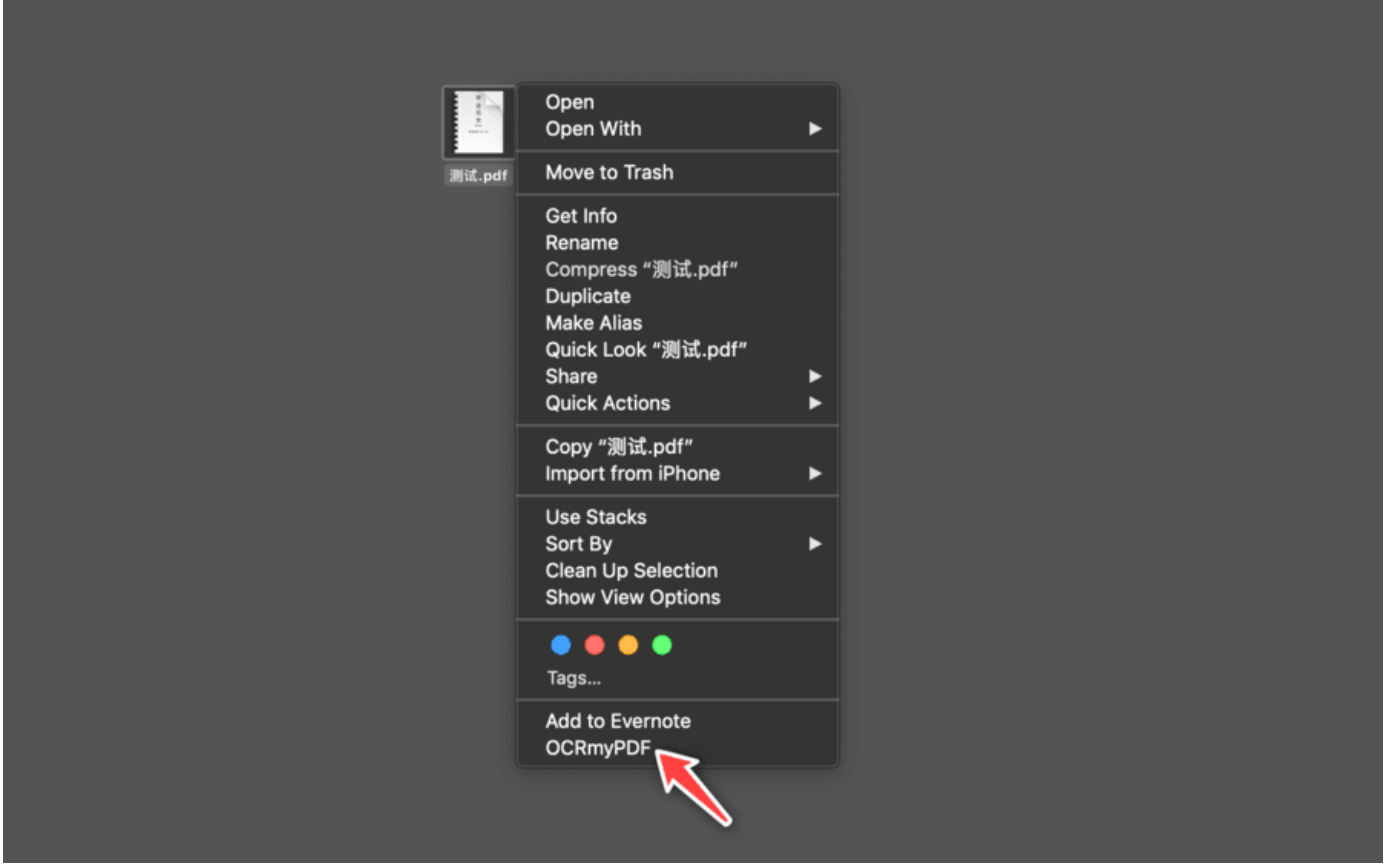

OCR 功能在右键菜单里

动作运行结束后再打开 PDF，就能进行搜索了。其实不光在 PDF 文档里面可以搜索，直接用 Spotlight、Finder 也能搜刚才处理过的 PDF，很方便。

通过 Spotlight 搜索到了 ocrmypdf 处理过的文件

除了右键菜单，刚才你下载的 Automator Workflow 还可以当作快速操作来用，直接在 Finder 的 PDF 预览面板里进行 OCR 识别。

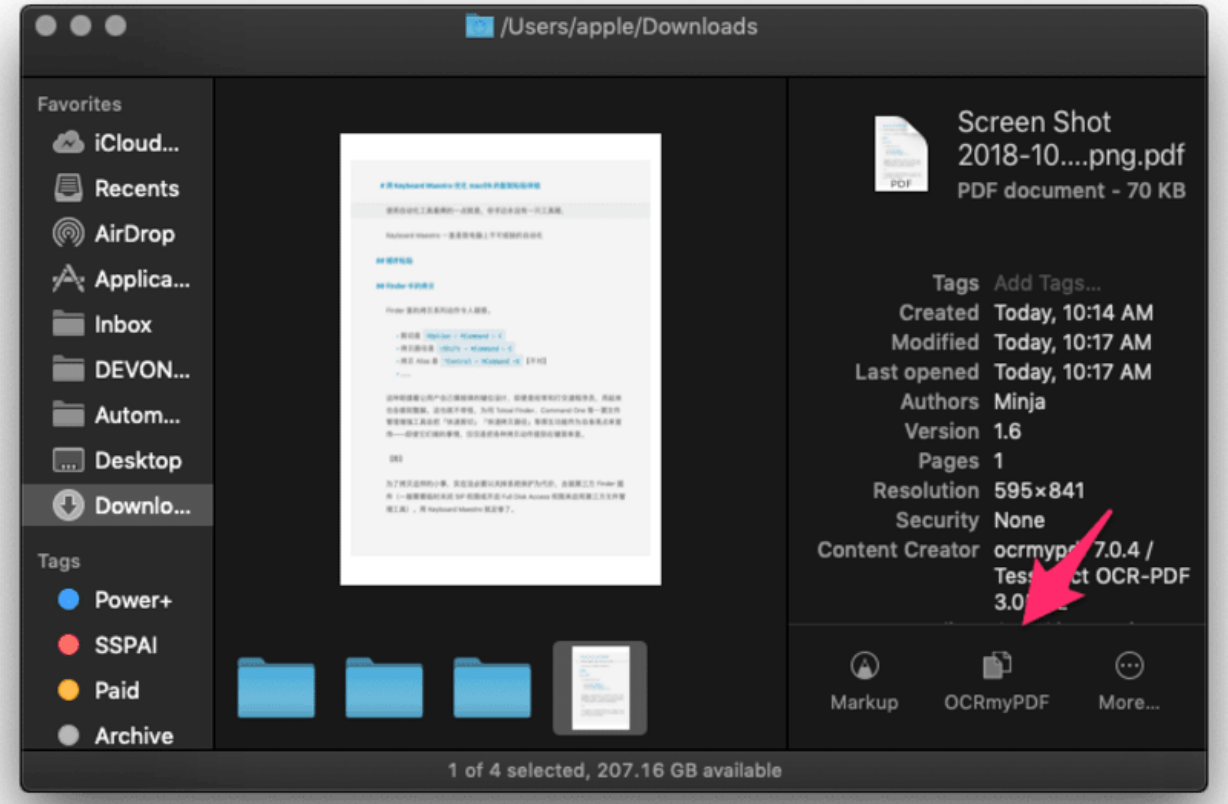

把 OCR 动作集成到 Finder

ocrmypdf 的功能非常强大，我只用到了其中的中文和英文 OCR 功能，如果你还要和其他语种打交道的话，不妨读读契丹神童的文章，试着自己配置语言包。

推荐阅读：《通过 OCRmyPDF 实现在扫描版 PDF 中检索文字》

技巧五：批量制作 PDF

PDF 最「本职」的工作，估计就是作为一种万能的打印格式。不少人都有给文印店 PDF 文档的好习惯，即便店里设备再古董，打印出来格式也不太会出错。

不过对于制作 PDF 的人来说，可能就要花点力气了，遇上期末、项目截止时文档较多，还挺麻烦。**下面的两个自动化方法可以一次性把各类常见文档转换成 PDF，方便打印。**

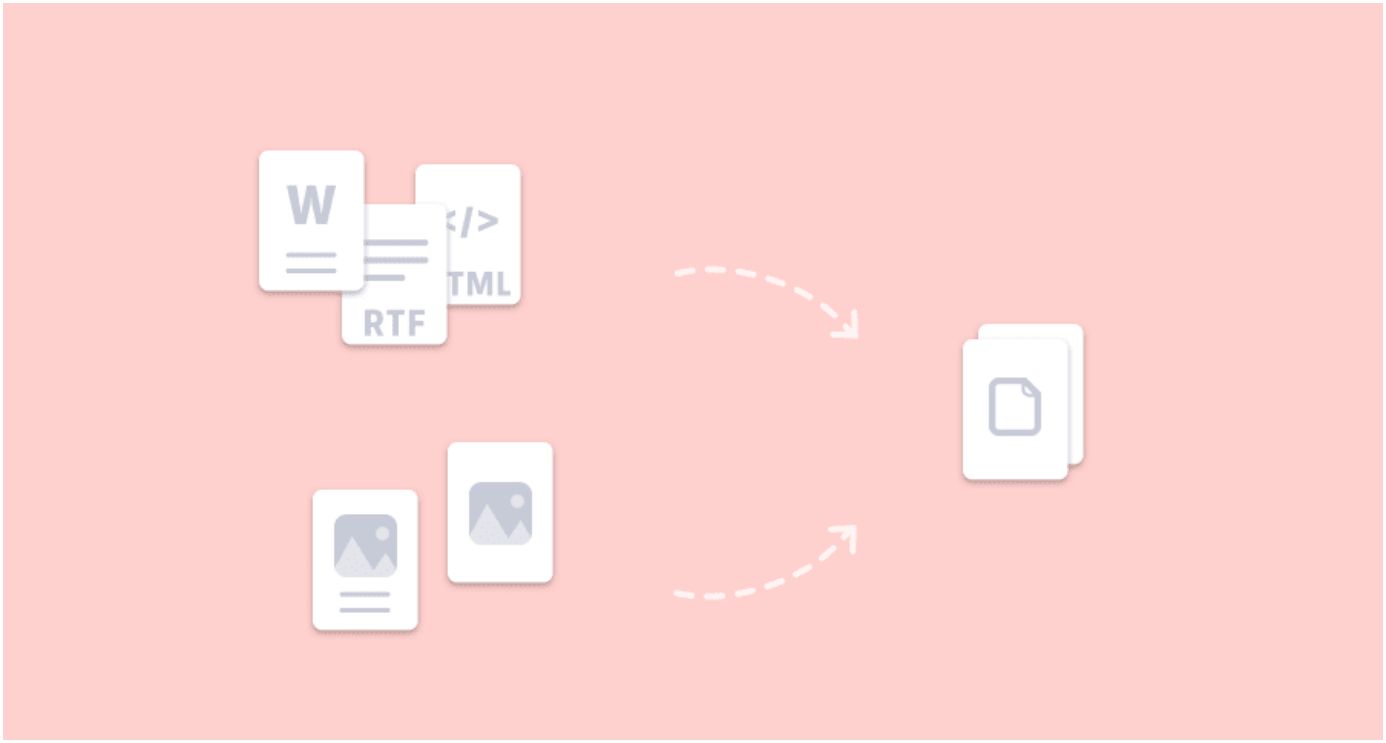

各种格式的文章转换成 PDF

文本文档转换成 PDF

不含图片的文档主要有 3 类[5]

：

1. Docx 文档
2. HTML 文件
3. RTF 富文本文件

它们转换起来比较容易，在 macOS 上不用下载任何第三方工具，全靠系统工具就能解决。动作我已经做好，大家可以

直接下载，解压后双击安装到右键菜单就能用了。

> 动作下载 🔗

注：本动作对于 RTF 和 HTML 文件支持良好，部分在 Docx 文档可能丢失格式。

稍微留意上面的视频，你会发现，**我这个动作不仅可以批量转换 PDF，而且 3 类文档通吃，一起选中也照样处理掉**。其实背后的原理挺简单的，就是根据不同文件格式、套用不同的系统命令[6]

。具体的代码我们不展开，只需简单了解一下上面 3 类文件的转换过程，以后遇到需要转格式的情况，你也可以对症下药：

1. Docx 文档：先用 `textutil` 命令生成 HTML，再用 `cupsfilter` 命令转换成 PDF。
2. RTF 文件：先用 `textutil` 命令生成 HTML，再用 `cupsfilter` 命令转换成 PDF。
3. HTML 文件：直接用 `cupsfilter` 命令转换成 PDF。

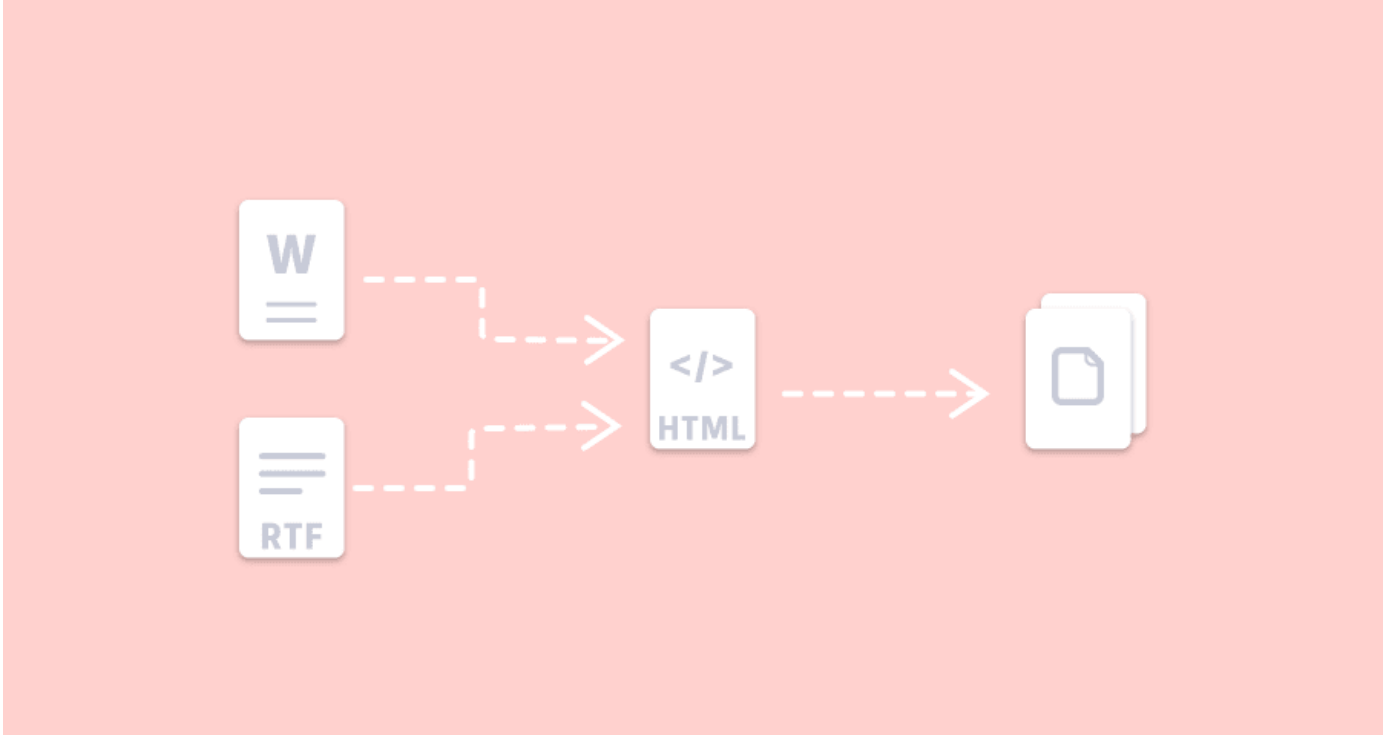

3 类文档的转换流程

含图片的文档转换成 PDF

如果是嵌有图片的文档，上面的方法就不起作用了，不过我们仍然有一个原生方案。

macOS 的老玩家可能还记得，可以安装 Office 套件，然后搭配 Automator 实现 Word 到 PDF 的转换。**其实有个很取巧的办法，完全用不着 Office，用免费的 Pages 就可以生成 PDF，而且通吃 Docx 和 Pages 文档。**

和前几节一样，这次动作还是 Automator Services，装好后同样会出现在右键菜单里。**一次性选中几个 Docx 和 Pages 文档，然后运行这个动作，稍等一会儿几份 PDF 就导出来了。**

> 动作下载 🔗

就像视频所演示的，只要你愿意，Docx 和 Pages 文档混着一起转换也行，照样能够打印成功。

动作原理并不复杂，只是把日常的「导出」操作写进了 AppleScript 脚本里面；有意思的地方在于，Pages 是可以打开预览（但是一些 Word 专有样式会丢失）Docx 文档的，所以不需要进行任何优化就可以让 AppleScript 像处理原生 Pages 文档一样打印 Docx——反正就是所见即所得嘛，没有什么深奥的东西。

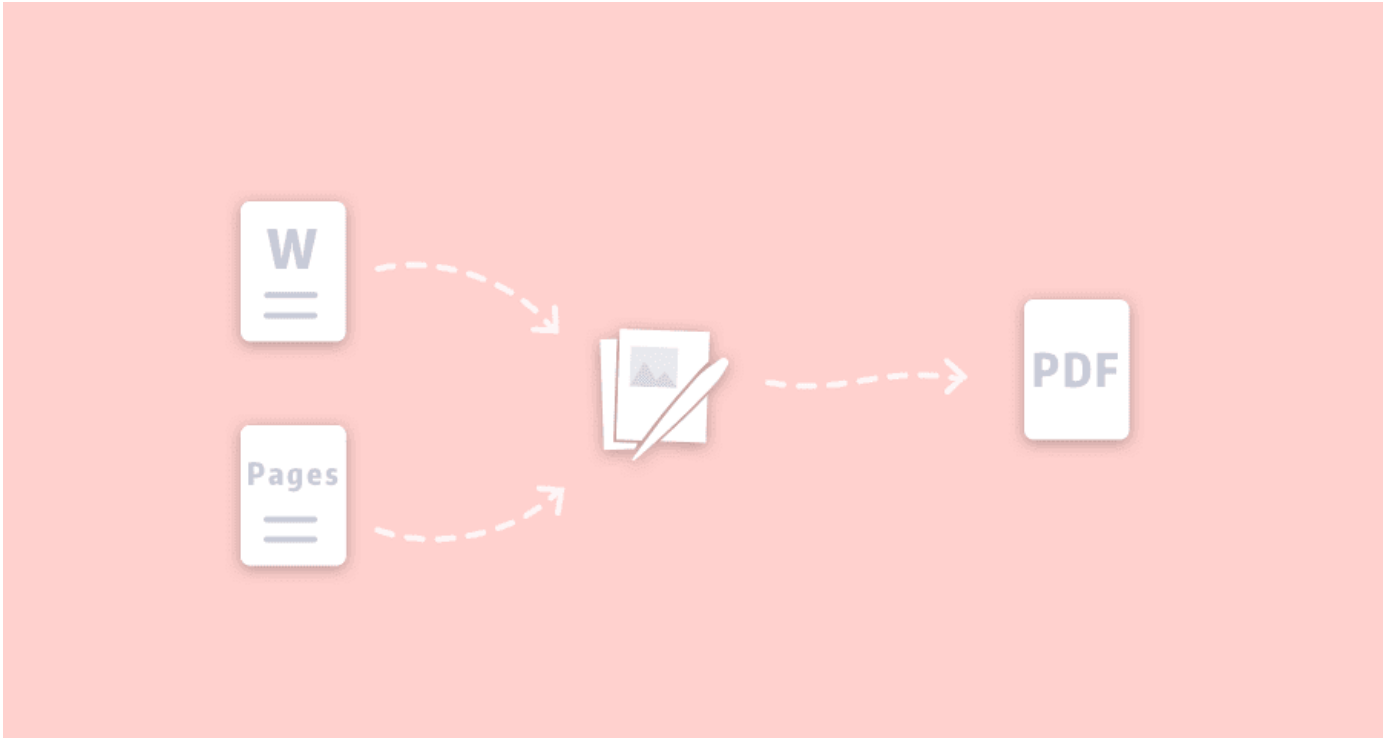

通过 Pages 打印带图片的文档

小结

PDF 固然是一种方便的预览格式，而「看」以外的操作，往往不是它的特长。条件允许的话，应该选择 Word、Markdown 等更适宜的文档格式。

由于种种原因，我们仍然需要用到 PDF，而且涉及从页面调整到文本搜索等不属于其本职的操作。遇到这些情况，就需要一些巧劲儿了。